TOR VERGATA
UNIVERSITÀ DEGLI STUDI DI ROMA
Macroarea di Ingegneria
Dipartimento di Ingegneria Civile e Ingegneria Informatica

Sincronizzazione nei Sistemi Distribuiti

Corso di Sistemi Distribuiti e Cloud Computing
A.A. 2023/24

Valeria Cardellini

Laurea Magistrale in Ingegneria Informatica

Il tempo nei SD

- In un SD, i processi
  - vengono eseguiti su nodi connessi in rete
  - cooperano per portare a termine una computazione
  - comunicano tramite scambio di messaggi
- Osservazioni*:*
  - Molti algoritmi distribuiti richiedono sincronizzazione
    - Ovvero i processi in esecuzione su diversi nodi del SD devono avere una nozione comune di tempo per poter effettuare azioni sincronizzate rispetto al tempo
  - Molti algoritmi richiedono che gli eventi siano ordinati
    - Nei SD i messaggi arrivano con dei timestamp in modo che si possa sapere in che ordine devono essere eseguiti
- *Conseguenza*: nei SD il tempo è un fattore critico

Il tempo nei SD

- In un sistema centralizzato è possibile stabilire l'ordine in cui gli eventi si sono verificati
  - Memoria comune e clock unico
- In un sistema distribuito è impossibile avere un unico clock fisico comune a tutti i processi
  - Eppure la computazione globale può essere vista come un ordine totale di eventi, se si considera il tempo in cui gli eventi sono stati generati
- Per numerosi problemi nei SD è di vitale importanza risalire a questo tempo, o comunque è importante stabilire l'**ordinamento degli eventi**, ovvero quale evento è stato generato prima di un altro. **Come?**

Il tempo nei SD: soluzioni

- Soluzione 1: **sincronizzazione degli orologi fisici**
  - Il middleware di ogni nodo del SD aggiusta il valore del suo clock fisico in modo coerente con quello degli altri nodi o con quello di un clock di riferimento
- Soluzione 2: **sincronizzazione degli orologi logici**
  - Leslie Lamport ha dimostrato come in un SD non sia necessaria la sincronizzazione degli orologi fisici, ma lo sia solo l'ordinamento degli eventi

Modello della computazione distribuita

- Componenti del SD: *N* processi e canali di comunicazione
- Ogni processo p_i ($1 \le i \le N$) genera una sequenza di eventi
  - Eventi ***interni*** (cambiamento dello stato del processo) ed ***esterni*** (send/receive di messaggi)
  - e_i^k: *k*-esimo evento generato da p_i
- L'evoluzione della computazione può essere visualizzata con un *diagramma spazio-tempo*

  $\rightarrow_i$: relazione di ordinamento tra due eventi in p_i

  $e \rightarrow_i e'$ se e solo se *e* è accaduto prima di e' in p_i

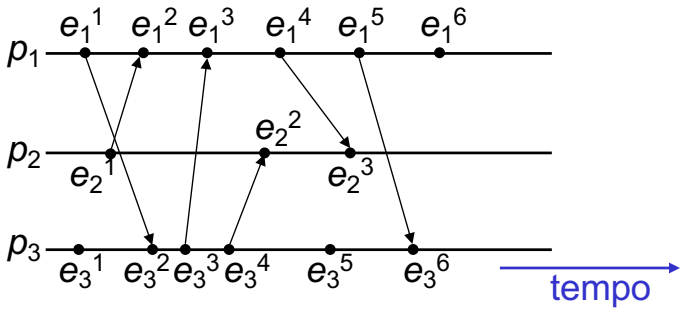

Timestamping

- Ogni processo etichetta gli eventi con un **timestamp**
- Soluzione semplice: ogni processo etichetta gli eventi in base al proprio clock fisico
- Funziona?
  - Possiamo ricostruire l'ordinamento di eventi avvenuti su uno stesso nodo
  - Ma l'ordinamento di eventi avvenuti su nodi diversi?
  - In un sistema distribuito è *impossibile* avere un unico clock fisico condiviso da tutti i processi

SD sincroni e asincroni

- Proprietà di un **SD sincrono**
  1. Esistono dei vincoli sulla velocità di esecuzione di ciascun processo
     - Il tempo di esecuzione di ciascuno passo è limitato, sia con lower bound che con upper bound
  2. Ciascun messaggio trasmesso su un canale di comunicazione è ricevuto in un tempo limitato
  3. Ciascun processo ha un clock fisico con un tasso di scostamento (*clock drift rate*) dal clock reale conosciuto e limitato

- In un **SD asincrono**
  - *Non ci sono vincoli* sulla velocità di esecuzione dei processi, sul ritardo di trasmissione dei messaggi e sul tasso di scostamento dei clock

Soluzioni per sincronizzare i clock

- Prima soluzione
  - Tentare di sincronizzare con *una certa approssimazione* i clock fisici dei processi attraverso opportuni algoritmi
  - Ogni processo può etichettare gli eventi con il valore del suo clock fisico (che risulta sincronizzato con gli altri clock con una certa approssimazione)
  - Timestamping basato su tempo fisico (***clock fisico***)

- E' sempre possibile mantenere limitata l'approssimazione dei clock fisici?
  - **No** in un SD asincrono
  - In un SD asincrono il timestamping non può basarsi sul tempo fisico, bensì sul tempo logico *(**clock logico**)*

Clock fisico

- All'istante di tempo reale t, il sistema operativo legge il tempo dal clock hardware $H_i(t)$ del computer e produce il clock software

  $$C_i(t) = aH_i(t) + b$$

  che approssimativamente misura l'istante di tempo fisico t per il processo p_i
  - Ad es. $C_i(t)$ è un numero a 64 bit che fornisce i nsec trascorsi da un istante di riferimento fino all'istante t
  - In generale il clock non è completamente accurato: può essere diverso da t
  - Se C_i si comporta abbastanza bene, può essere usato per il timestamping degli eventi di p_i
- Quale deve essere la risoluzione del clock per poter distinguere due eventi?

  $T_{risoluzione} < \Delta T$ tra due eventi rilevanti

Clock fisici in un SD

- In un SD clock fisici diversi con possibili valori diversi
- *Skew*: differenza istantanea fra il valore di due clock
- *Drift*: i clock contano il tempo con frequenze differenti (a causa di variazioni fisiche), quindi nel tempo divergono rispetto al tempo reale
- *Drift rate*: differenza per unità di tempo di un clock rispetto ad un orologio ideale
  - Ad es. drift rate di 2 μsec/sec significa che il clock incrementa il suo valore di 1 sec+2 μsec ogni secondo
  - Drift rate di normali orologi al quarzo: 10^{-6} s/s (circa 1 s in 11-12 giorni)
  - Drift rate di orologi al quarzo ad alta precisione: 10^{-7} o 10^{-8} s/s
  - A causa del drift rate, dopo un certo intervallo di tempo i clock di un SD saranno di nuovo disallineati → occorre eseguire una sincronizzazione periodica per riallineare i clock

UTC

- Universal Coordinated Time (UTC): riferimento internazionale per il tempo
- Basato sul tempo atomico, occasionalmente corretto utilizzando il tempo astronomico
  - 1 sec = tempo impiegato dall'atomo di cesio 133 per compiere 9192631770 transizioni di stato
- Clock fisici che usano oscillatori atomici sono i più accurati (drift rate pari a 10^{-13} s/s)
- L'output dell'orologio atomico è inviato in broadcast da stazioni radio su terra e da satelliti (es. GPS)
  - In Italia: Istituto Galileo Ferraris
- Nodi con ricevitori possono sincronizzare i loro clock con questi segnali
  - Segnali da stazioni radio su terra: accuratezza nell'intervallo 1-10 ms
  - Segnali da satellite: accuratezza da 0.5 ms fino a 50 ns

Sincronizzazione di clock fisici

- Come sincronizzare i clock fisici con l'orologio atomico oppure tra di loro?
- Sincronizzazione **esterna**

  I clock C_i (per i = 1, 2, … N) sono sincronizzati con una sorgente di tempo S (UTC), in modo che, dato un intervallo I di tempo reale:

  $|S(t) - C_i(t)| \leq \alpha$ per $1 \leq i \leq N$ e per tutti gli istanti in I
  - I clock C_i hanno **accuratezza** α, *con* $\alpha>0$
- Sincronizzazione **interna**

  Due clock C_i e C_j sono sincronizzati l'uno con l'altro in modo che:

  $|C_i(t) - C_j(t)| \leq \pi$ per $1 \leq i,j \leq N$ nell'intervallo I
  - I clock C_i e C_j hanno **precisione** π, *con* $\pi>0$

Sincronizzazione di clock fisici

Sincronizzazione interna

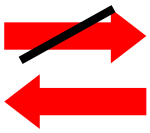

Sincronizzazione esterna

- Clock sincronizzati internamente non sono necessariamente sincronizzati anche esternamente
  - Tutti i clock possono deviare collettivamente da una sorgente esterna sebbene rimangano tra loro sincronizzati entro il bound *D*
- Se l'insieme dei processi è sincronizzato esternamente con accuratezza α, allora è anche sincronizzato internamente con precisione 2α

Correttezza di clock fisici

- Un clock hardware *H* è *corretto* se il suo drift rate è compreso tra $-\rho$ e $+\rho$ con $\rho > 0$
- Se il clock *H* è corretto, l'*errore* che si commette nel misurare un intervallo di istanti reali $[t, t']$ (con $t'>t$) è *limitato*:

$$(1 - \rho)\,(t' - t) \leq H(t') - H(t) \leq (1 + \rho)\,(t' - t)$$

  - Si evitano "salti" del valore del clock
- Per il clock software *C* spesso basta una condizione di monotonicità

  $t' > t$ *implica* $C(t') > C(t)$

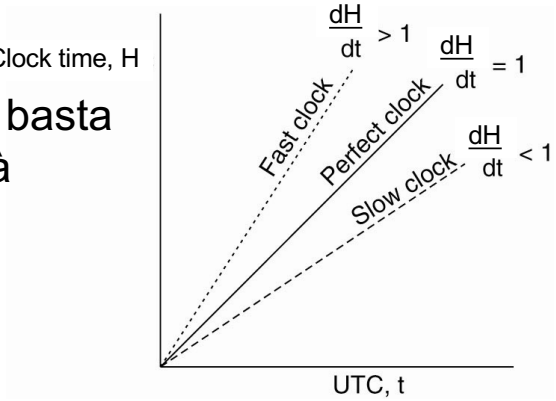

Quando sincronizzare i clock fisici?

- Consideriamo 2 clock aventi lo stesso tasso di scostamento massimo (*maximum clock drift rate*) da UTC pari a ρ
- Ipotizziamo che dopo la sincronizzazione i 2 clock si scostino da UTC in senso opposto
  - Dopo Δt dalla sincronizzazione, si saranno scostati al più di $2\rho\ \Delta t$
- Affinché i 2 clock non differiscano più di δ, occorre sincronizzarli almeno ogni $\delta/(2\rho)$

Sincronizzazione interna in un SD sincrono

- Algoritmo di sincronizzazione **interna** tra 2 processi in un **SD sincrono**
  1. p_1 manda il suo clock locale t a p_2 tramite un messaggio m, con tempo di trasmissione pari a T_{trasm}
  2. p_2 riceve m e imposta il suo clock a $t + T_{trasm}$
     T_{trasm} non è noto ma, essendo il SD sincrono, $T_{min} \leq T_{trasm} \leq T_{max}$
     Sia $u = (T_{max} - T_{min})$ l'incertezza sul tempo di trasmissione
  3. Se p_2 imposta il suo clock a $t + (T_{max} + T_{min})/2$, il lower bound ottimo sullo skew tra i due clock è pari a $u/2$
- L'algoritmo può essere generalizzato per sincronizzare N processi, con lower bound ottimo sullo skew pari a $u(1-1/N)$
- In un SD asincrono $T_{trasm} = T_{min} + x$, con $x \geq 0$ e non noto
  - Occorrono altri algoritmi di sincronizzazione dei clock fisici

Sincronizzazione fisica mediante time service

- Un time service può fornire l'ora con precisione
  - Dotato di un ricevitore UTC o di un clock accurato
- Il gruppo di processi che deve sincronizzarsi usa un time service
  - Time service: centralizzato oppure distribuito
- Time service centralizzato
  - Request-driven: algoritmo di Cristian (1989)
    - Sincronizzazione esterna
  - Broadcast-based: algoritmo di Berkeley Unix - Gusella & Zatti (1989)
    - Sincronizzazione interna
- Time service distribuito
  - Network Time Protocol
    - Sincronizzazione esterna

Algoritmo di Cristian

- Un time server *S* (*passivo*) riceve il segnale da una sorgente UTC (sincronizzazione esterna)
- Un processo *p* richiede il tempo con un messaggio m_r e riceve *t* nel messaggio m_t da *S*
- *p* imposta il suo clock a $t + T_{round}/2$
  - T_{round} è il round trip time (RTT) misurato da *p*

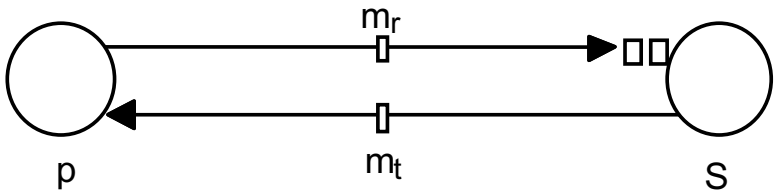

- Osservazioni
  - Singolo time server potrebbe guastarsi
    - Soluzione: usare un gruppo di time server sincronizzati
  - Non gestiti time server maliziosi
  - Accuratezza ragionevole solo se T_{round} è breve → adatto per reti locali con bassa latenza

Algoritmo di Cristian: accuratezza

Caso 1: *S* non può mettere *t* in m_t prima che sia trascorso *min* dall'istante in cui *p* ha inviato m_r
- *min* è il minimo tempo di trasmissione tra *p* e *S*

Caso 2: *S* non può mettere *t* in m_t dopo il momento in cui m_t arriva a *p* meno *min*

- Il tempo su S quando m_t arriva a *p* è compreso in $[t + min, t + T_{round} - min]$
  - L'ampiezza di tale intervallo è $T_{round} - 2\ min$
- Accuratezza α: $\pm (T_{round}/2 - min)$

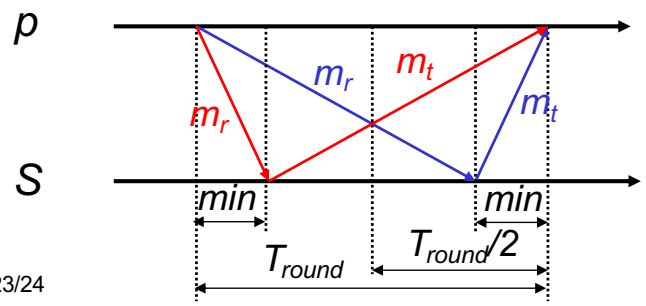

Algoritmo di Berkeley

- Algoritmo per la sincronizzazione interna di un gruppo di nodi
- Il nodo *master* (time server *attivo*) richiede in broadcast il valore dei clock degli altri nodi (*worker*)
- Il master usa i RTT per stimare i valori dei clock dei worker
  - δ_i: differenza tra clock del master *M* e clock del worker i (si calcola in modo simile all'algoritmo di Cristian)

    $\delta_i = (C_M(t_1) + C_M(t_3))/2 - C_i(t_2)$

    $C_M(t_1)$ e $C_M(t_3)$: clock su M all'invio e ricezione

    $C_i(t_2)$: clock su *i*

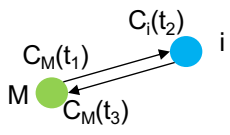

- Il master calcola la media delle differenze dei clock
- Il master invia un valore correttivo ai worker
  - Se il valore correttivo prevede un salto indietro nel tempo, il worker non imposta il nuovo valore ma rallenta il clock

Algoritmo di Berkeley: esempio

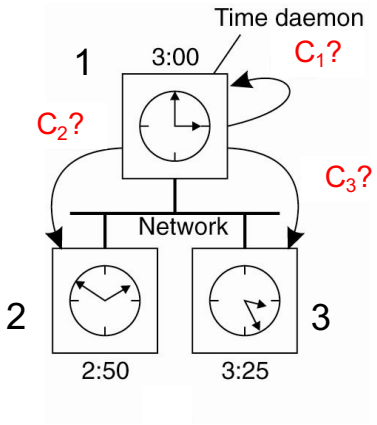

Il master chiede ai worker e a se stesso il valore dei clock

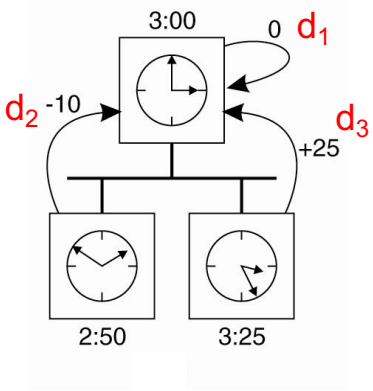

Il master calcola la media delle differenze dei clock pari a
avg = (-10+25+0)/3 = 5

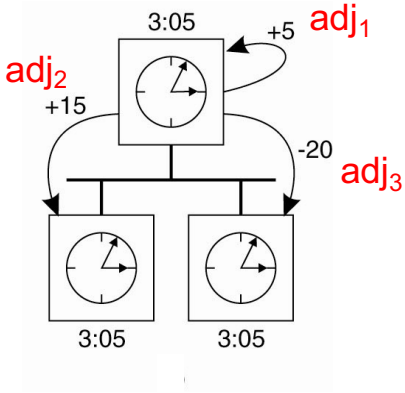

Il master invia ai worker l'aggiustamento dei clock ($adj_i = avg - d_i$)

Algoritmo di Berkeley: caratteristiche

- Precisione dipende da RTT nominale massimo: il master non considera valori di clock associati a RTT superiori al massimo
  - Si scartano gli outlier
- Tolleranza ai guasti
  - Se il master cade, un altro nodo viene eletto come master
    - Tramite un algoritmo di elezione
  - Tollerante a comportamenti arbitrari (worker che inviano valori errati di clock)
    - Il master considera solo quei valori di clock che differiscono tra loro al più per una soglia specificata

Algoritmo di Berkeley: slowdown del clock

- Che cosa significa rallentare un clock?
- Non si può imporre un valore di tempo passato ai worker che hanno un valore di clock superiore a quello calcolato come clock comune
  - Ciò provocherebbe un problema di ordinamento causa/effetto di eventi e verrebbe violata la condizione di monotonicità del tempo
- La soluzione consiste nel mascherare una serie di interrupt che fanno avanzare il clock locale in modo da rallentarne l'avanzata
  - Il numero di interrupt mascherati è pari al tempo di slowdown diviso il periodo di interrupt del processore

Network Time Protocol (NTP)

- Time service per Internet (standard in RFC 5905)
  - Sincronizzazione esterna accurata rispetto a UTC
  - Servizio configurabile su diversi SO. In GNU/Linux: demone `ntpd`, comando `ntpdate` per sincronizzare manualmente
- Architettura di time service disponibile e scalabile
  - Time server e path ridondanti
- Autenticazione delle sorgenti di tempo

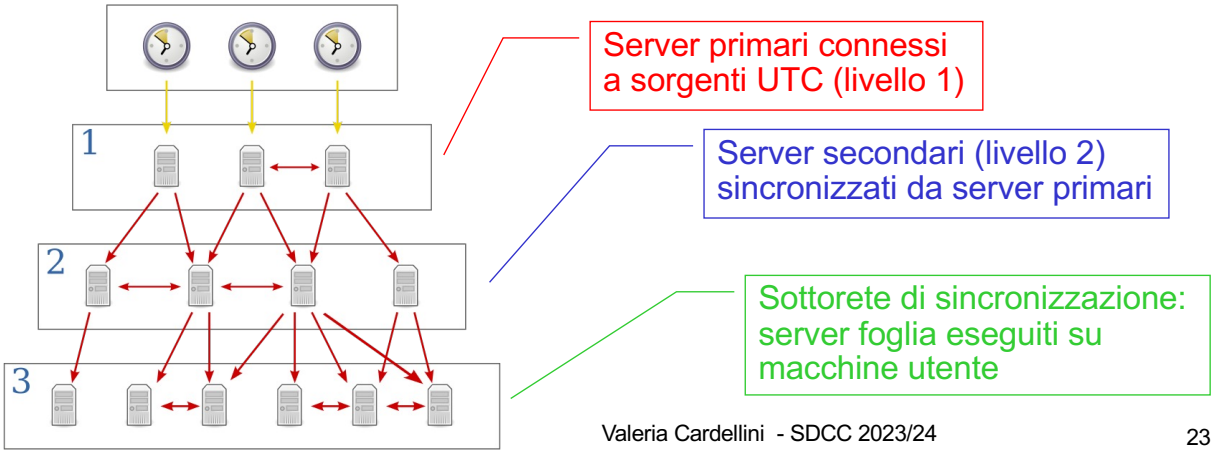

NTP: sincronizzazione

- La sottorete di sincronizzazione si riconfigura in caso di guasti
  - Server primario che perde la connessione alla sorgente UTC diventa server secondario
  - Server secondario che perde la connessione al suo primario (ad es. crash del primario) può usare un altro primario

NTP: modi di sincronizzazione

- Modi di sincronizzazione
  - **Multicast**: server all'interno di LAN ad alta velocità invia in multicast il suo clock agli altri server, che impostano il tempo ricevuto assumendo un certo ritardo di trasmissione
    - Accuratezza relativamente bassa
  - **Procedure call**: un server accetta richieste da altri (come algoritmo di Cristian)
    - Accuratezza maggiore rispetto a multicast
    - Utile se non è disponibile multicast
  - **Simmetrico**: coppie di server scambiano messaggi contenenti informazioni sul timing
    - Accuratezza molto alta (usato per livelli alti della gerarchia)
- Tutti i modi di sincronizzazione usano UDP

NTP: modo simmetrico

- I server A e B si scambiano coppie di messaggi (m, m') per migliorare l'accuratezza della loro sincronizzazione
- Ogni messaggio NTP contiene timestamp di eventi recenti, ad es. m' contiene
  - Tempo su B di *send* di m' (T_{i-1})
  - Tempo su A di *send* di m (T_{i-3}) e tempo su B di *receive* di m (T_{i-2})
- Il server A registra il tempo di receive di m' (T_i)
- Il tempo tra l'arrivo di m e l'invio di m' (T_{i-1}-T_{i-2}) può essere non trascurabile

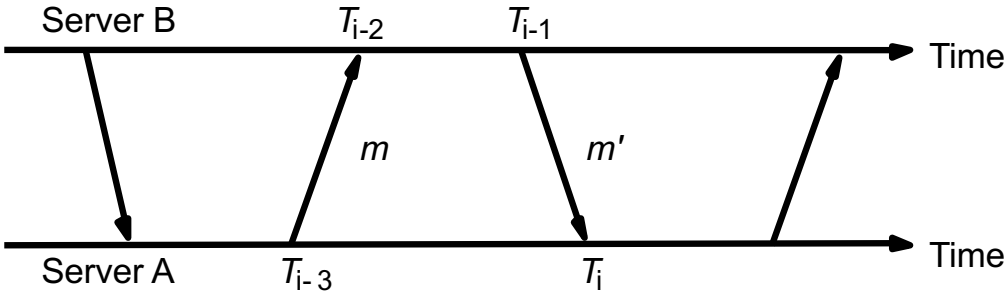

NTP: accuratezza

- Per ogni coppia di messaggi m ed m' scambiati tra 2 server, NTP stima l'offset o_i tra i 2 clock e il ritardo d_i (pari al tempo totale di trasmissione di m ed m')

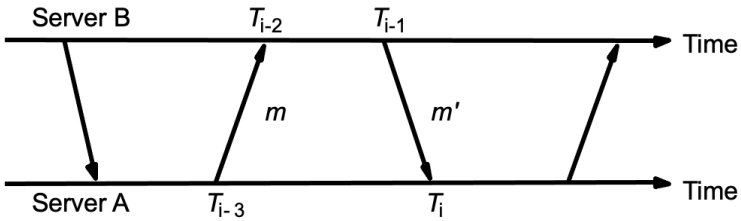

- Indicando con:
  - o: offset reale del clock di B rispetto al clock di A (o = $clock_B$ - $clock_A$)
  - t e t': tempi effettivi di trasmissione di m ed m' rispettivamente
- si ha

$$T_{i-2} = T_{i-3} + t + o \quad \text{e} \quad T_i = T_{i-1} + t' - o$$
$$d_i = t + t' = T_{i-2} - T_{i-3} + T_i - T_{i-1}$$

- Sottraendo le equazioni per T_{i-2} e T_i ed esplicitando rispetto ad o:

$$o = [(T_{i-2} - T_{i-3}) + (T_{i-1} - T_i)]/2 + (t' - t)/2$$

ponendo $o_i = [(T_{i-2} - T_{i-3}) + (T_{i-1} - T_i)]/2$ si ha

$$o = o_i + (t' - t)/2$$

- Poiché t, $t' > 0$ si dimostra che $o_i - d_i/2 \le o \le o_i + d_i/2$
- Quindi: o_i è la stima dell'offset e $d_i/2$ l'accuratezza di questa stima

NTP: accuratezza

- I server NTP applicano un algoritmo di filtraggio statistico sulle 8 coppie $<o_i, d_i>$ più recenti, scegliendo come stima di o il valore di o_j corrispondente al minimo d_j
- Applicano poi un algoritmo di selezione dei peer per modificare eventualmente il peer da usare per sincronizzarsi www.eecis.udel.edu/~mills/ntp/html/warp.html
- Accuratezza di NTP:
  - 10 ms su Internet
  - 1 ms su LAN

Perfect synchronization over networks is actually impossible

Google's TrueTime (TT)

- Distributed synchronized clock with bounded non-zero error
  - Designed by Google for Spanner, a global-scale, multiversion, distributed NewSQL database
  - Relies on a well-engineered tight clock synchronization available on all Google servers thanks to GPS and atomic clocks
  - Enables applications to generate monotonically increasing timestamps
  - *Cons*: TT requires special hardware and custom-build tight clock synchronization protocol, which is infeasible for many systems
    - Google also relies on its very high throughput, global fiber optic network linking its data centers

Tempo nei SD asincroni

- Gli algoritmi per la sincronizzazione dei clock fisici si basano sulla stima dei tempi di trasmissione
  - Possiamo determinare l'accuratezza conoscendo upper e lower bound del tempo di trasmissione
- Ma in un SD asincrono, no vincoli sui tempi di trasmissione → non possiamo ordinare gli eventi che accadono in nodi diversi usando il tempo fisico
- Tuttavia, di solito ci interessa soltanto che i processi concordino sull'ordine in cui si verificano gli eventi, piuttosto che sul tempo in cui sono avvenuti
  - Il tempo fisico non è più importante, usiamo il tempo logico

Tempo logico

- Idea: ordinare gli eventi in base a 2 osservazioni intuitive:
  1. Due eventi occorsi sullo stesso processo p_i si sono verificati esattamente nell'ordine in cui p_i li ha osservati
  2. Quando un messaggio viene inviato da p_i a p_j, l'evento di *send* precede l'evento di *receive*

- Lamport (1978) introduce il concetto di relazione di ***happened-before*** (anche detta relazione di *precedenza* o *ordinamento causale*)
  - $\rightarrow_i$: relazione di ordinamento tra due eventi occorsi su p_i
  - $\rightarrow$: relazione di happened-before tra due eventi qualsiasi

L. Lamport, Time, Clocks and the Ordering of Events in Distributed Systems, Comm. ACM, 1978

Relazione happened-before

- Due eventi *e* ed *e'* sono in relazione di happened-before (indicata con $e \rightarrow e'$) se è vero uno dei seguenti casi:
  1. $\exists\ p_i \mid e \rightarrow_i e'$
  2. $e = send(m) \wedge e' = receive(m)$
     e è l'evento di invio del messaggio *m*, *e'* è il corrispondente evento di ricezione
  3. $\exists\ e, e', e'' \mid (e \rightarrow e'') \wedge (e'' \rightarrow e')$
     Ovvero la relazione happened-before è transitiva
- Applicando i tre casi è possibile costruire una sequenza di eventi $e_1, e_2, \ldots, e_n$ causalmente ordinati
- *Osservazioni*
  - La relazione happened-before rappresenta un ordinamento parziale (proprietà: *non riflessivo*, *antisimmetrico*, *transitivo*)
  - Non è detto che la sequenza $e_1, e_2, \ldots, e_n$ sia unica
  - Data una coppia di eventi, questa non è sempre legata da una relazione happened-before; in questo caso si dice che gli eventi sono *concorrenti* (indicato da ||)

Relazione happened-before: esempio

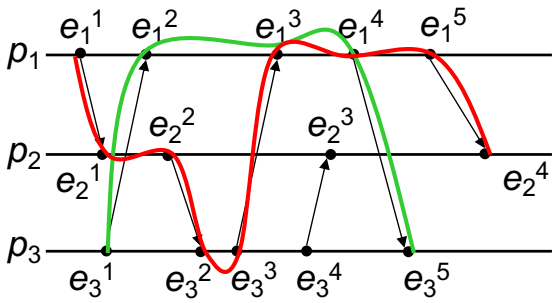

- Sequenza $s_1 = e_1^1, e_2^1, e_2^2, e_3^2, e_3^3, e_1^3, e_1^4, e_1^5, e_2^4$
- Sequenza $s_2 = e_3^1, e_1^2, e_1^3, e_1^4, e_3^5$

- Gli eventi e_3^1 ed e_2^1 sono concorrenti
  $e_3^1 \not\rightarrow e_2^1$ ed $e_2^1 \not\rightarrow e_3^1$

Clock logico scalare

- Il clock logico è un contatore software *monotonicamente crescente,* il cui valore non ha alcuna relazione con il clock fisico
- Ogni processo p_i ha il proprio clock logico L_i e lo usa per applicare i *timestamp* agli eventi
- Denotiamo con $L_i(e)$ il timestamp, basato sul clock logico, applicato dal processo p_i all'evento e
- Proprietà: **se $e \rightarrow e'$ allora $L(e) < L(e')$**
- *Osservazione*:
  - Se $L(e) < L(e')$ non è detto che $e \rightarrow e'$; tuttavia, $L(e) \not< L(e')$ implica che $e \not\rightarrow e'$
  - Happened-before introduce un ordinamento parziale degli eventi: nel caso di eventi concorrenti non è possibile stabilire quale evento avviene effettivamente prima

Clock logico scalare: implementazione

- Algoritmo di Lamport
- Ogni processo p_i inizializza il proprio clock logico L_i a 0 ($\forall\ i = 1, \ldots, N$)
- Prima di eseguire un evento interno, p_i incrementa L_i di 1: $L_i = L_i + 1$
- Quando p_i invia il messaggio m a p_j
  - Incrementa il valore di L_i: $L_i = L_i + 1$
  - Allega al messaggio m il timestamp $t = L_i$
  - Esegue l'evento *send*(m)
- Quando p_j riceve il messaggio m con timestamp t
  - Aggiorna il proprio clock logico $L_j = max(t, L_j)$
  - Incrementa il valore di L_j: $L_j = L_j + 1$
  - Esegue l'evento *receive*(m)

Clock logico scalare: esempio

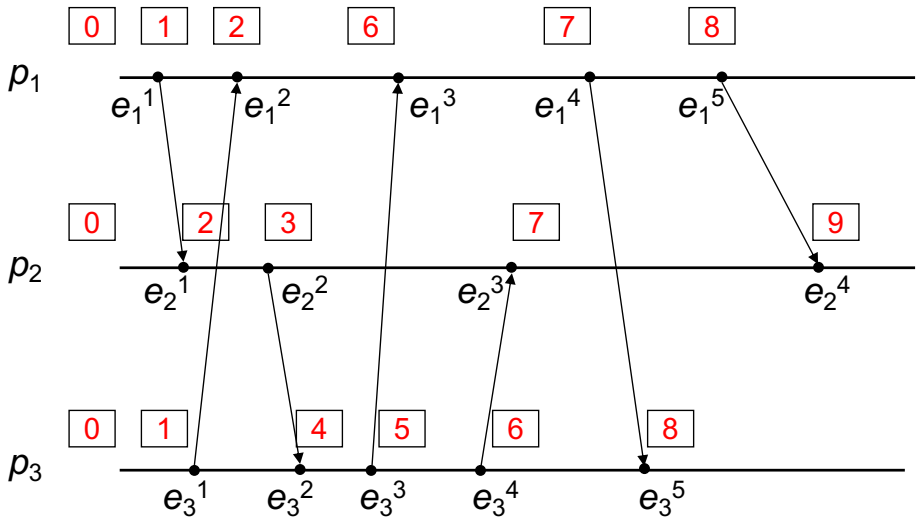

Clock logico scalare: esempio

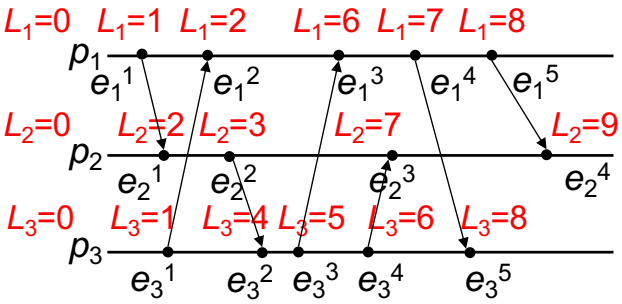

- Osservazioni
  - $e_1^1 \rightarrow e_2^1$ ed i relativi timestamp riflettono questa proprietà (L_1=1 e L_2=2); infatti *if* $e_1^1 \rightarrow e_2^1$ *then* $L(e_1^1) < L(e_2^1)$
  - $e_1^1 \parallel e_3^1$ ed i relativi timestamp sono uguali (L_1=1 e L_3=1); infatti *if* $L(e_1^1) \geq L(e_3^1)$ then $e_1^1 \not\rightarrow e_3^1$
  - $e_2^1 \parallel e_3^1$ ed i relativi timestamp sono diversi (L_2=2 e L_3=1); infatti *if* $L(e_2^1) \geq L(e_3^1)$ then $e_2^1 \not\rightarrow e_3^1$

Ordinamento totale

- Usando il clock logico scalare, due o più eventi possono avere stesso timestamp: come realizzare un ordinamento totale tra eventi, evitando così che due eventi accadano nello *stesso tempo logico*?
- Soluzione: oltre al clock logico, usiamo il numero del processo su cui è avvenuto l'evento
  - Si stabilisce un ordinamento totale ($\prec$) tra i processi
- Relazione di ordine totale tra eventi (indicata con $e \Rightarrow e'$): se e è un evento di p_i ed e' è un evento di p_j allora $e \Rightarrow e'$ se e solo:
  1. $L_i(e) < L_j(e')$ or
  2. $L_i(e) = L_j(e')$ and $p_i \prec p_j$
- Relazione applicata in alcuni algoritmi di mutua esclusione distribuita

Relazione di ordine totale: esempio

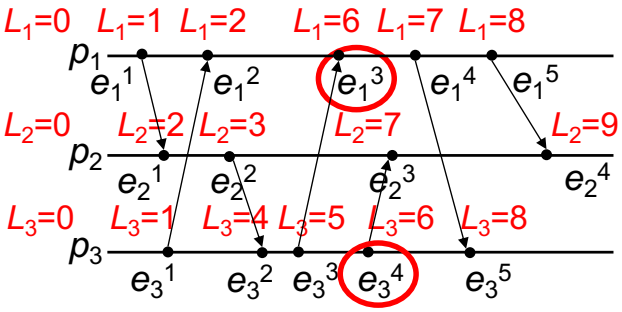

- e_1^3 e e_3^4 hanno lo stesso valore di clock logico: come ordinarli?
- $e_1^3 \Rightarrow e_3^4$ poiché $L_1(e_1^3) = L_3(e_3^4)$ e $p_1 \prec p_3$

Clock logico scalare: limitazione

- Il clock logico scalare ha la seguente proprietà
  - Se $e \rightarrow e'$ allora $L(e) < L(e')$
- Ma non è possibile assicurare che
  - Se $L(e) < L(e')$ allora $e \rightarrow e'$

    Esempio slide 36: $L(e_3^1) < L(e_2^1)$ ma $e_3^1 \parallel e_2^1$
- Conseguenza: non è possibile stabilire, solo guardando i clock logici scalari, se due eventi sono concorrenti o meno

- Come superare questa limitazione?
- Introducendo i clock logici vettoriali: ad opera di Mattern (1989) e Fidge (1991)

Clock logico vettoriale

- Il clock logico vettoriale per un sistema con N processi è un vettore di N interi
- Ciascun processo p_i mantiene il proprio clock vettoriale V_i
- Per il processo p_i $V_i[\,i\,]$ è il clock logico locale
- Ciascun processo usa il suo clock vettoriale per assegnare il timestamp agli eventi
- Analogamente al clock scalare di Lamport, il clock vettoriale viene allegato al messaggio m ed il timestamp diviene vettoriale
- Con il clock vettoriale si catturano completamente le caratteristiche della relazione happened-before

$$e \rightarrow e' \text{ se e solo se } V(e) < V(e')$$

Clock logico vettoriale: significato e confronto

- Dato il clock vettoriale V_i
  - $V_i[\,i\,]$ è il numero di eventi generati da p_i
  - $V_i[\,j\,]$ con $i \neq j$ è il numero di eventi occorsi a p_j di cui p_i ha conoscenza

- Confronto di clock vettoriali
  - $V = V'$ se e solo se $\forall\, j$: $V[\,j\,] = V'[\,j\,]$
  - $V \leq V'$ se e solo se $\forall\, j$: $V[\,j\,] \leq V'[\,j\,]$
  - $V < V'$ (e quindi l'evento associato a V precede quello associato a V') se e solo se
    - $\forall\, i \in [1,\ldots,N]$: $V[\,i\,] \leq V'[\,i\,]$

      and
    - $\exists\, j \in$ in $[1,\ldots,N]$: $V[\,j\,] < V'[\,j\,]$
  - $V \,||\, V'$ (e quindi l'evento associato a V è concorrente a quello associato a V') se e solo se
    - not($V < V'$) and not($V' < V$)

Clock logico vettoriale: implementazione

- Ogni processo p_i inizializza il proprio clock vettoriale V_i

  $V_i[k]=0 \quad \forall\, k = 1, 2, \ldots, N$
- Prima di eseguire un evento interno, p_i incrementa di 1 la sua componente $V_i[i]$

  $V_i[i] = V_i[i] + 1$
- Quando p_i invia il messaggio m a p_j
  - Incrementa di 1 la sua componente $V_i[i]$: $V_i[i] = V_i[i] + 1$
  - Allega al messaggio m il timestamp vettoriale $t = V_i$
  - Esegue l'evento *send*(m)
- Quando p_j riceve il messaggio m con timestamp t
  - Aggiorna il proprio clock logico $V_j[k] = max(t[k], V_j[k]) \;\forall\, k = 1, 2, \ldots, N$
  - Incrementa di 1 la sua componente $V_j[j]$: $V_j[j] = V_j[j] + 1$
  - Esegue l'evento *receive*(m)

Clock logico vettoriale: esempio

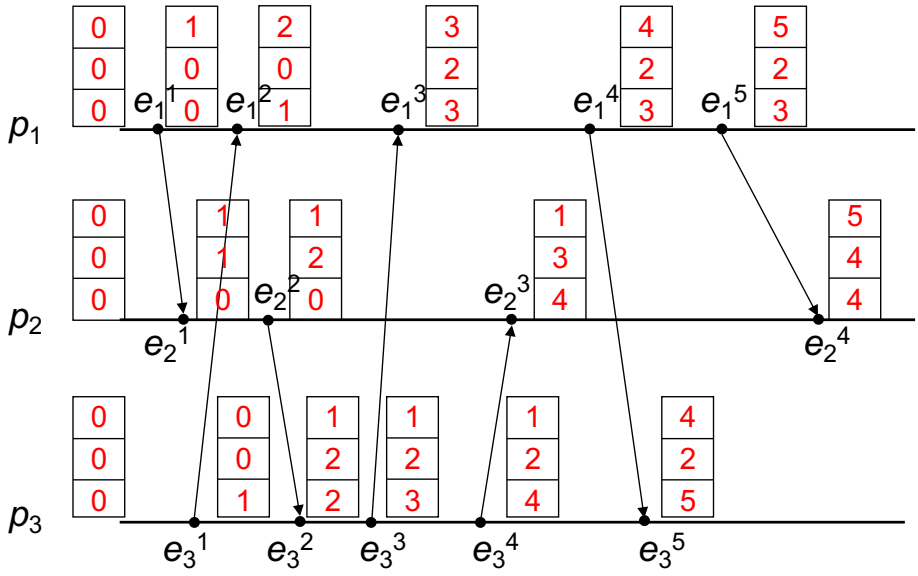

Confronto di clock vettoriali

- Confrontando i timestamp basati su clock vettoriale si può capire se gli eventi sono concorrenti o in relazione happened-before

V	V'
1	1
2	2
0	2

V(e) < V'(e) e quindi e $\rightarrow$ e'

V	V'
1	1
2	0
0	2

V(e) $\neq$ V'(e) e quindi e || e'

Esempi di applicazione del clock logico

- Esaminiamo due applicazioni del clock logico scalare e vettoriale

1. Clock logico scalare per multicasting totalmente ordinato
2. Clock logico vettoriale per multicasting causalmente ordinato

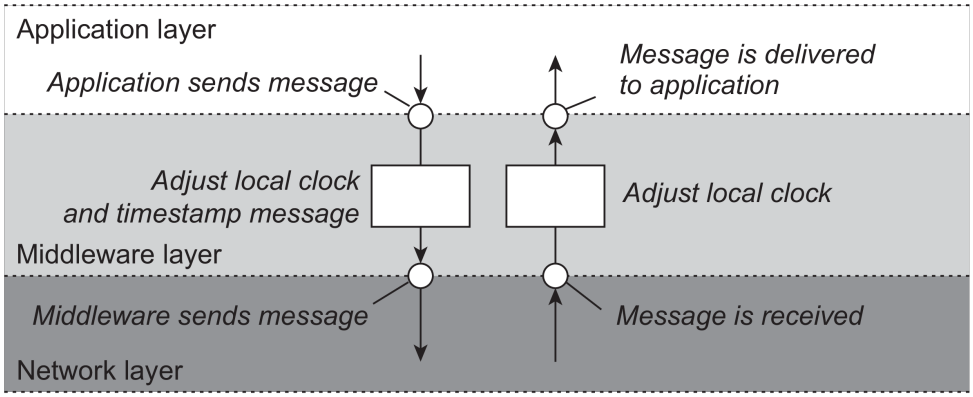

Multicasting totalmente ordinato: problema

- Come garantire che aggiornamenti concorrenti su un database replicato siano visti nello stesso ordine da ogni replica?
  - p_1: aggiungi \$100 ad un conto (valore iniziale: \$1000)
  - p_2: incrementa il conto dell'1%
  - Ci sono due repliche
  - In assenza di sincronizzazione può accadere che i due aggiornamenti non vengano eseguiti nello stesso ordine
    - Replica #1 ← 1111 (prima p_1 e poi p_2)
    - Replica #2 ← 1110 (prima p_2 e poi p_1)

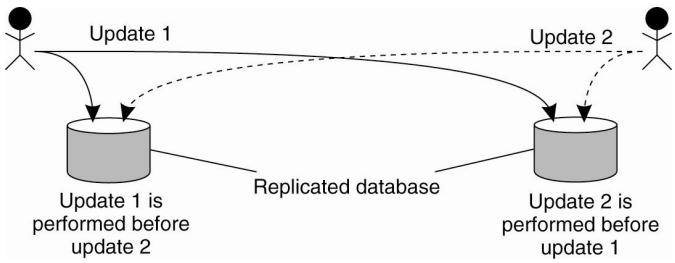

Multicasting totalmente ordinato

- **Multicasting totalmente ordinato**: operazione di multicast con cui tutti i messaggi sono consegnati *nello stesso ordine* ad ogni destinatario
- Assunzioni: comunicazione *affidabile* e *FIFO ordered*
  - Comunicazione affidabile: no perdita di messaggi
  - Comunicazione FIFO ordered: messaggi inviati da p_i a p_j sono ricevuti da p_j nello stesso ordine in cui p_i li ha inviati
- Esaminiamo due soluzioni
  - Centralizzata
  - Distribuita, usando il clock logico scalare

Multicasting totalmente ordinato

- Soluzione centralizzata: coordinatore centralizzato (*sequencer*)
  - Ogni processo invia il proprio messaggio di update al sequencer
  - Il sequencer assegna ad ogni messaggio di update un numero di sequenza univoco e poi invia in multicast il messaggio a tutti i processi, che eseguono gli aggiornamenti in ordine in base al numero di sequenza
  - ✗ Problemi di scalabilità e single point of failure

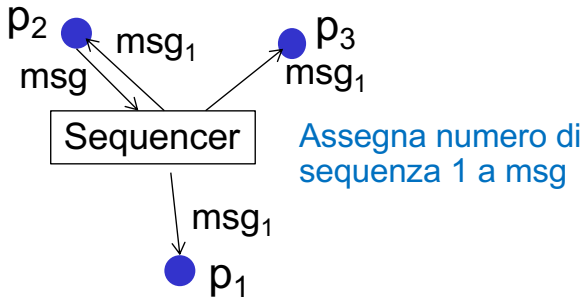

Multicasting totalmente ordinato

- Algoritmo distribuito: usiamo il clock logico scalare
  - Ogni messaggio è etichettato con il clock logico scalare del processo mittente

- p_i invia in multicast agli altri processi (incluso se stesso) il *messaggio di update* msg_i
- Ogni processo ricevente p_j mette msg_i in una coda locale $queue_j$, ordinata in base al valore del timestamp
- p_j invia in multicast altri altri processi un *messaggio di ack* della ricezione di msg_i
- p_j consegna msg_i all'applicazione se:
  1. msg_i è in testa a $queue_j$ (e tutti gli ack relativi a msg_i sono stati ricevuti da p_j)
  2. per ogni processo p_k c'è un messaggio msg_k in $queue_j$ *con* timestamp maggiore di quello di msg_i

  Ovvero msg_i viene consegnato solo quando p_j sa che nessun altro processo può inviare in multicast un messaggio con timestamp minore o uguale a quello di msg_i

Multicasting totalmente ordinato

- Costo di comunicazione:
  - N processi e per ogni messaggio ricevuto viene inviato un ack in multicast ➔ N^2 ack
  - ✗ Scalabilità limitata

- Meccanismo ideato da Lamport per **state-machine replication**

State machine replication

- Software replication technique applied to a service that can be implemented as a deterministic state machine

  Next state of service =

  f(current state, command executed)

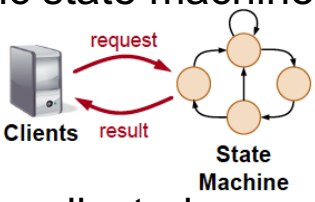

- To achieve fault tolerance, service is replicated on several nodes, all of them running a state machine replication (SMR) middleware
  - Set of replicas behaves as a “centralized” server
- All replicas execute commands in the same order
- If deterministic and by executing commands in the same order, all replicas end up in same state
- Service makes progress as long as any majority of replicas are up

Multicasting causalmente ordinato

- **Multicasting causalmente ordinato**: un messaggio viene consegnato solo se tutti i messaggi che lo precedono *causalmente* (relazione di causa-effetto) sono stati già consegnati
  - Relazione di causa-effetto tra due eventi: il secondo evento è *potenzialmente* influenzato dal primo evento
    - Obiettivo: consegnare prima la causa e poi l’effetto
  - Indebolimento del multicasting totalmente ordinato
  - Esempio:
    - p_1 invia i messaggi m_A ed m_B
    - p_2 invia i messaggi m_C ed m_D
    - m_A causa m_C
    - Alcune sequenze di consegna compatibili con l’ordinamento causale (e FIFO ordered) sono:

      $m_A\ m_B\ m_C\ m_D$ $m_A\ m_C\ m_B\ m_D$ $m_A\ m_C\ m_D\ m_B$

      ma NON $m_C\ m_A\ m_B\ m_D$

Multicasting causalmente ordinato

- Assunzioni: comunicazione *affidabile* e *FIFO ordered*
- Applichiamo il clock logico vettoriale per risolvere il problema del multicasting causalmente ordinato in modo decentralizzato
  - p_i invia il messaggio m usando come timestamp ts_m il clock logico vettoriale V_i
    - $V_j[i]$ conta il numero di messaggi inviati da p_i a p_j
  - p_j riceve m da p_i e ne ritarda la consegna all'applicazione (ponendo m in una coda di attesa) finché non si verificano entrambe le condizioni
    1. $ts_m[i] = V_j[i] + 1$

       m è il messaggio successivo che p_j si aspetta da p_i
    2. $ts_m[k] \leq V_j[k] \ \forall \ k \neq i$

       per ogni altro processo p_k, p_j ha visto almeno gli stessi messaggi visti da p_i

Multicasting causalmente ordinato: esempio

- p_1 invia m a p_2 e p_3
- p_2, dopo aver ricevuto m, invia m^* a p_1 e p_3: relazione di causa-effetto
- Supponiamo che p_3 riceva m^* prima di m: l'algoritmo evita la violazione della causalità tra m e m^*, facendo sì che p_3 consegni prima m e poi m^* all'applicazione

Aggiornamento clock

p_i invia msg: $V_i[i] = V_i[i] + 1$
p_i riceve msg con ts_{msg}: $V_i[k] = \max\{ V_i[k], t_{msg}[k] \}$

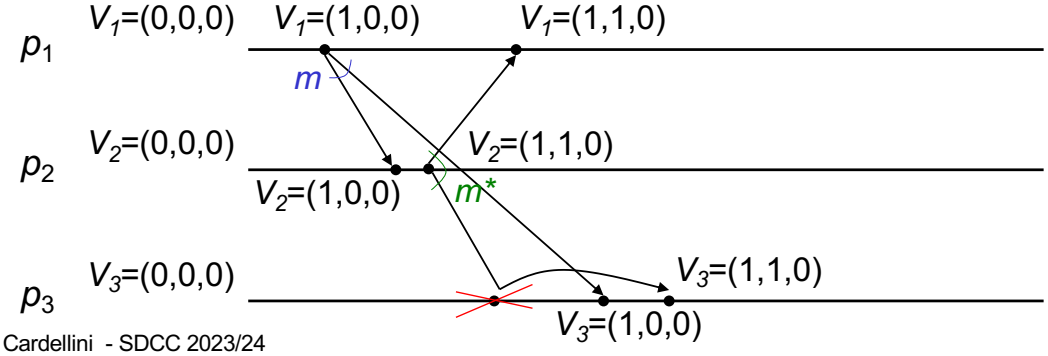

Timestamp in pratica

- Utile confrontare i timestamp di eventi, ad es. per
  - Riconciliare gli aggiornamenti apportati ad un oggetto in un sistema di storage distribuito
  - Ripristinare lo stato di un sistema dopo un crash

    1. Effettua checkpoint del sistema; 2. Registra gli eventi (con timestamp); 3. Dopo un crash ripristina il checkpoint e riproduci gli eventi in ordine
- Come confrontare i timestamp tra processi diversi?
  - Timestamp fisico: richiede la sincronizzazione fisica dei clock
    - Es: Spanner di Google usa TrueTime
  - Timestamp logico: non possiamo distinguere completamente tra eventi in relazione causale ed eventi concorrenti
    - Oracle DB usa "system change numbers" basati sul clock logico
  - Timestamp vettoriale: messaggi di dimensioni maggiori
    - DynamoDB di Amazon utilizza clock vettoriali per determinare qual è la versione più recente di un oggetto

References

- Sections 5.1 and 5.2 of van Steen & Tanenbaum book
- Sections 14.1 - 14.4 of Coulouris et al. book
- Lamport, Time, clocks and the ordering of events in a distributed system, Comm. ACM, 1978
- Raynal and Singhal, Logical time: Capturing causality in distributed systems, IEEE Computer, 1996